

تحريث: نفرض  $X \sim N(\mu, \sigma^2)$  وليكن  $X_1, X_2, \dots, X_6$  عينات لـ  $X$  وليكن  $T_1 = a \{ (X_1 - X_2)^2 + (X_3 - X_4)^2 + (X_5 - X_6)^2 \}$  مقدرًا نظريًا لـ  $\sigma^2$  و المطلوب:

- عينة ثابتة  $a$  من أجل أن يكون  $T_1$  مقدرًا عشوائيًا لـ  $\sigma^2$
- نفرض أن:  $T_2 = \frac{1}{5} \sum_{i=1}^6 (X_i - \bar{X})^2$  مقدرًا آخر لـ  $\sigma^2$  عندئذ بيّن أياهما المقدرين أكثر (أفضل) ..

الحل: لدينا فرضنا:  $ET_1 = \sigma^2$  ولدينا  $X_1 - X_2 \sim N(0, 2\sigma^2)$  أيضًا  $X_3 - X_4 \sim N(0, 2\sigma^2)$  و  $X_5 - X_6 \sim N(0, 2\sigma^2)$

$$\frac{T_1}{2a\sigma^2} = \underbrace{\left( \frac{X_1 - X_2 - 0}{\sqrt{2}\sigma} \right)^2}_{\chi^2(1)} + \underbrace{\left( \frac{X_3 - X_4 - 0}{\sqrt{2}\sigma} \right)^2}_{\chi^2(1)} + \underbrace{\left( \frac{X_5 - X_6 - 0}{\sqrt{2}\sigma} \right)^2}_{\chi^2(1)}$$

$$\frac{T_1}{2a\sigma^2} \sim \chi^2(3)$$

در درجات الحرية

$$E\left(\frac{T_1}{2a\sigma^2}\right) = 3 \Rightarrow \frac{1}{2a\sigma^2} ET_1 = 3 \Rightarrow$$

$$ET_1 = \sigma^2 \quad \text{بالفرض}$$

$$ET_1 = 6a\sigma^2 \Rightarrow \sigma^2 = 6a\sigma^2 \Rightarrow$$

$$6a = 1 \Rightarrow a = \frac{1}{6}$$

أي أن:

$$T_1 = \frac{1}{6} \{ (X_1 - X_2)^2 + (X_3 - X_4)^2 + (X_5 - X_6)^2 \}$$

هذا يعني أن:

$$\frac{6T_1}{2\sigma^2} \sim \chi^2(3) \Rightarrow V\left(\frac{3T_1}{\sigma^2}\right) = \sigma^2 \Rightarrow$$

$$\frac{9}{\sigma^4} V(T_1) = 6 \Rightarrow V(T_1) = \frac{6}{9} \sigma^4 \Rightarrow V(T_1) = \frac{2}{3} \sigma^4$$

$$\frac{5T_2}{\sigma^2} = \sum_{i=1}^6 \left( \frac{X_i - \bar{X}}{\sigma} \right)^2 \sim \chi^2(5)$$



$$E\left(\frac{5T_2}{\sigma^2}\right) = 5 \Rightarrow \frac{5}{\sigma^2} E T_2 = 5 \Rightarrow E T_2 = \sigma^2$$

$$V\left(\frac{5T_2}{\sigma^2}\right) = \frac{25}{\sigma^4} V(T_2) = 10 \Rightarrow V(T_2) = \frac{10\sigma^4}{25}$$

$$= \frac{2}{5} \sigma^4 = \frac{6}{15} \sigma^4$$

$$V(T_1) = \frac{2}{3} \sigma^4 = \frac{10}{15} \sigma^4 \Rightarrow V(T_2) < V(T_1)$$

وبالتالي فإن  $V(T_2)$  أفضل (أكثر) من  $V(T_1)$ .

الإحصاء الكاف (المقدّر الكاف):

\* نعرفه لدينا مجتمع إحصائي معروف بتوزيع احتمالي وسيط، المجهول  $\theta$  ولناخذ من عين عشوائية بحجم  $n$  كذا: نقول عن المقدّر  $T$  النقطة الوسطي  $\theta$  أنه إحصاء كافٍ إذا أعطت معلومات كافية عن هذا الوسطي وذلك على أساس هذه العين وحدها أن أثبت أن هذا هو إحصاء كافٍ يوجد لدينا قاي تين ← القاي الأول: هو أن يكون

$$\textcircled{1} - P(x_1, x_2, \dots, x_n | T = t)$$

حال عن الوسطي  $\theta$  هذا يعني أن  $T$  إحصاء كافٍ

$$P(x_1, x_2, \dots, x_n | T)$$

التوزيع الاحتمالي المشترك لتغيرات العين

$$\textcircled{2} L = P(x_1, x_2, \dots, x_n, \alpha) = \sum_{i=1}^n P_{x_i}(x_i, \alpha) = g(t, \alpha) \cdot H(x_1, \dots, x_n) \quad \left\{ \begin{array}{l} g(t, \alpha) \text{ دالة كائنة عن } \theta \\ f(x_1, x_2, \dots, x_n, \alpha) = \prod_{i=1}^n f_{x_i}(x_i, \alpha) \end{array} \right.$$

$$= g(t, \alpha) \cdot H(x_1, \dots, x_n)$$

مثال: نعرفه لدينا مجتمعاً إحصائياً بنولياً وسيطاً  $\mu$  ولناخذ من عين عشوائية بحجم  $n$  كذا: بين أن الإحصاء  $T = \sum_{i=1}^n X_i$  عند إحصاء كافٍ



التوزيع الاحتمالي

$$P_X(x, p) = p^x (1-p)^{1-x} ; x = 0, 1$$

$$L = \prod_{i=1}^n P_{\sum_{i=1}^n x_i} (x_i, p) = p^{\sum_{i=1}^n x_i} (1-p)^{n - \sum_{i=1}^n x_i}$$

$$P(x_1, \dots, x_n / T=t) = \frac{P(x_1, x_2, \dots, x_n / t = \sum_{i=1}^n x_i)}{P_T(t)}$$

$$= \frac{P(X_1=x_1, X_2=x_2, \dots, X_n=x_n, T=t)}{P(T=t)}$$

$$= \frac{P(x_1, x_2, \dots, x_n)}{P(T=t)} = \frac{p^{\sum_{i=1}^n x_i} (1-p)^{n - \sum_{i=1}^n x_i}}{P_T(t)}$$

نكتب كليا عام، لتوزيع الاحتمالي  $T$

$$M_{\sum_{i=1}^n X_i}(t) = (M_X(t))^n = (q + pe^t)^n \Rightarrow \text{دالة المولدة، مولدة لثبات}$$

$$P_T(t) = C_t^n p^t q^{n-t}$$

$$\rightarrow = \frac{p^t q^{n-t}}{C_t^n p^t q^{n-t}} = \frac{1}{C_t^n}$$

دعنا نرى أنه حال من العسيلة  $p$  من العينة  $n$ ، لتوزيع المستند، لشروط حال من العسيلة  $C_t^n$  والتالي  $T = \sum_{i=1}^n X_i$  عتلى امصدر كامباً للعسيلة  $p$

$$L = p^{\sum_{i=1}^n x_i} (1-p)^{n - \sum_{i=1}^n x_i} = p^t (1-p)^{n-t} = (C_t^n p^t (1-p)^{n-t}) \frac{1}{C_t^n}$$

$$= g(t, p) \cdot H(x_1, x_2, \dots, x_n)$$

أي أنه استطعنا كتابة  $L$  على المجتمع الإحصائي  $H$  شكل مبراد والتعبير الأولي تابع لـ  $p, t$  وتمثل توزيعاً احتمالياً لبرنولي وسطحه الأول  $p$  والثاني  $n$  والثاني تابع فقط لتغيرات العينة العشوائية وهي  $H$  التابعة لـ  $x$



مثال: نفرض لدينا توزيعاً احتمالياً معصوماً بهالة كثافة احتمالية

$$p(x, \alpha) = \frac{1}{\alpha} e^{-\frac{x}{\alpha}} \quad x > 0$$

هناك ما من هذا التوزيع حيث عشوائية بسيط  $n$  كذا

بين أن:  $T = \sum_{i=1}^n X_i$  محل ابعاد كافي لـ  $\alpha$

الحل: لدينا:

$$f(x_1, x_2, \dots, x_n / t) = \frac{f(x_1, \dots, x_n)}{f_T(t)}$$

$$= \frac{\prod_{i=1}^n f_{X_i}(x_i)}{f_T(t)} = \frac{1}{\alpha^n} e^{-\frac{\sum_{i=1}^n x_i}{\alpha}} f_T(t)$$

والآن سوف نحسب دالة الكثافة  $T$  عن طريق الحالة الأولى:

$$M \sum_{i=1}^n X_i(t) = (M_{X_i}(t))^n = (1 - \alpha t)^{-n} = (1 - \alpha t)^{-n}$$

وهي دالة مولدة للمعادى وسيطة الأول:  $\lambda = n$  وسيطة الثاني

$$f_T(t) = \frac{\alpha^n}{\Gamma(n)} t^{n-1} e^{-\alpha t} = \frac{1}{\alpha^n \Gamma(n)} t^{n-1} e^{-\frac{t}{\alpha}}$$

$\alpha = \frac{1}{\alpha}$  وبالتالي

وهي دالة الكثافة الاحتمالية للإحصاء  $T$  وبالتالي:

$$f(x_1, x_2, \dots, x_n / t) = \frac{1}{\alpha^n} e^{-\frac{t}{\alpha}}$$

$$\frac{1}{\alpha^n \Gamma(n)} t^{n-1} e^{-\frac{t}{\alpha}}$$

فإن هذه الوسيطة  $\alpha$  هنا حيث أن  $T = \sum_{i=1}^n X_i$  محل ابعاد كافي

طريقة أخرى:

$$L = \prod_{i=1}^n f(x_i, \alpha) = \prod_{i=1}^n \frac{1}{\alpha} e^{-\frac{x_i}{\alpha}}$$

$$= \frac{1}{\alpha^n} e^{-\frac{\sum_{i=1}^n x_i}{\alpha}} = \frac{1}{\alpha^n} e^{-\frac{t}{\alpha}} = \frac{1}{\alpha^n \Gamma(n)} t^{n-1} e^{-\frac{t}{\alpha}} \frac{\Gamma(n)}{t^{n-1}}$$

وهي دالة كثافة لتفاوت وسيطة  $n, \alpha$

$$= g(t, \alpha) \cdot H(x_1, \dots, x_n)$$



## معلومات فيشر

إذا كان لدينا مجموعاً آمياً فعموماً يتوزع أمثالي وسيطاً المجهول  $\theta$  ولنا من حيث عشوائية العينة  $n$  كذاً بالتحريف .. معلومات فيشر: هي المعلومات التي تعطىها العينة لعشوائية  $\theta$  حول  $\theta$  الوسيط  $\theta$  و  $\theta$  جاد هذه المعلومات نضعها في:

لدينا  $L$  على التقريب الأمثالي، مستنداً لمغيرات العينة كذاً على أن تكون:

$$\int_{R_n} L \cdot dV = 1 \quad \text{و} \quad dV = dx_1 \cdot dx_2 \cdots dx_n$$

نشتق طرف العلاقة (1) بالنسبة للوسيط  $\theta$  نجد أن:

$$\int_{R_n} \frac{\partial L}{\partial \theta} = 0 \Rightarrow \int_{R_n} \frac{\partial \ln L}{\partial \theta} \cdot L \cdot dV = 0$$

$$E\left(\frac{\partial \ln L}{\partial \theta}\right) = 0 \quad [2]$$

الآن سوف نشتق طرف العلاقة (2) بالنسبة ل  $\theta$  مرة أخرى

$$\int_{R_n} \left[ \frac{\partial^2 \ln L}{\partial \theta^2} \cdot L + \left(\frac{\partial \ln L}{\partial \theta}\right)^2 \cdot L \right] \cdot dV = 0$$

$$\int_{R_n} \left[ \frac{\partial^2 \ln L}{\partial \theta^2} + \left(\frac{\partial \ln L}{\partial \theta}\right)^2 \right] L \cdot dV = 0 \Rightarrow$$

$$E\left(\frac{\partial^2 \ln L}{\partial \theta^2} + \left(\frac{\partial \ln L}{\partial \theta}\right)^2\right) = 0 \Rightarrow$$

$$E\left(\frac{-\partial^2 \ln L}{\partial \theta^2}\right) = E\left(\frac{\partial \ln L}{\partial \theta}\right)^2$$

$$V\left(\frac{\partial \ln L}{\partial \theta}\right) = E\left(\frac{\partial \ln L}{\partial \theta}\right)^2 - \left(E\left(\frac{\partial \ln L}{\partial \theta}\right)\right)^2$$

$$\Rightarrow E\left(\frac{-\partial^2 \ln L}{\partial \theta^2}\right) = E\left(\frac{\partial \ln L}{\partial \theta}\right)^2 = V\left(\frac{\partial \ln L}{\partial \theta}\right)$$

وهي معلومات فيشر التي تعطىها العينة التي

عينة  $n$  حول الوسيط  $\theta$



$$I_1 = E\left(\frac{-\partial^2 \ln L}{\partial \alpha^2}\right) = V\left(\frac{\partial \ln L}{\partial \alpha}\right) = E\left(\frac{\partial \ln L}{\partial \alpha}\right)^2$$

ملحوظة: لدينا  $L = \prod_{i=1}^n f(x_i, \alpha)$   $\Rightarrow \ln L = \sum_{i=1}^n \ln f(x_i, \alpha)$

$$\frac{\partial \ln L}{\partial \alpha} = \sum_{i=1}^n \frac{\partial \ln f}{\partial \alpha} \Rightarrow \text{نشتق مرة أخرى}$$

$$\frac{\partial^2 \ln L}{\partial \alpha^2} = \sum_{i=1}^n \frac{\partial^2 \ln f}{\partial \alpha^2} \Rightarrow -\frac{\partial^2 \ln L}{\partial \alpha^2} = \sum_{i=1}^n -\frac{\partial^2 \ln f}{\partial \alpha^2}$$

$$E\left(-\frac{\partial^2 \ln L}{\partial \alpha^2}\right) = \sum_{i=1}^n E\left(-\frac{\partial^2 \ln f}{\partial \alpha^2}\right) \quad \text{نأخذ التوقع الرياضي للطرفية}$$

$$\Rightarrow I_2 = \sum_{i=1}^n I_f \Rightarrow \bar{I}_L = n \bar{I}_f$$

مثال: افترض لدينا مجموعاً آمالياً نواحيه توزيعاً بواسونياً  $\lambda$  ولدينا عينت عشوائية

$$L = \prod_{i=1}^n P_{X_i}(x_i, \lambda) = \prod_{i=1}^n e^{-\lambda} \frac{\lambda^{x_i}}{x_i!}$$

$$e^{-n\lambda} \lambda^{\sum_{i=1}^n x_i} \prod_{i=1}^n \frac{1}{x_i!}$$

نأخذ بوغاريتم الطرفية:

$$\ln L = -n\lambda + \sum_{i=1}^n x_i \ln \lambda - \sum_{i=1}^n \ln x_i!$$

نشتق الطرفية مرتين بالنسبة لـ  $\lambda$  فنجد أن:

$$\frac{\partial \ln L}{\partial \lambda} = -n + \frac{\sum x_i}{\lambda}$$

نشتق مرة أخرى بالنسبة لـ  $\lambda$  فنجد أن:

$$\frac{\partial^2 \ln L}{\partial \lambda^2} = -\frac{\sum x_i}{\lambda^2} \Rightarrow -\frac{\partial^2 \ln L}{\partial \lambda^2} = \frac{\sum x_i}{\lambda^2}$$

$$\Rightarrow E\left(-\frac{\partial^2 \ln L}{\partial \lambda^2}\right) = \frac{1}{\lambda^2} \sum_{i=1}^n E x_i \Rightarrow I_2 = \frac{n\lambda}{\lambda^2} = \frac{n}{\lambda}$$



وهي معلومات فيشر التي تفقد العينات التي حجمها  $n$  حول المعسلة  $\theta$   
مثال: مجتمع إحصائي موثوق به  $f(x) = \frac{1}{\theta} e^{-\frac{x}{\theta}}$  ;  $x > 0$   
 خلاف ذلك  $= 0$

ولنا هذه عينات عشوائية حجمها  $n$  والمطلوب إيجاد معلومات فيشر

الحل:  $L = \frac{1}{\theta^n} e^{-\sum_{i=1}^n \frac{x_i}{\theta}}$   $\xrightarrow[\text{الطرفية}]{\text{أخذ لوغاريتم}}$   $\ln L = -n \ln \theta - \frac{\sum_{i=1}^n x_i}{\theta}$

نشتق النسبة لـ  $\theta$ :

$$\frac{\partial \ln L}{\partial \theta} = -\frac{n}{\theta} + \frac{\sum_{i=1}^n x_i}{\theta^2}$$

نشتق مرة أخرى

$$\Rightarrow \frac{\partial^2 \ln L}{\partial \theta^2} = \frac{n}{\theta^2} - 2 \frac{\sum_{i=1}^n x_i}{\theta^3}$$

نغير إشارة (-)

$$\Rightarrow -\frac{\partial^2 \ln L}{\partial \theta^2} = -\frac{n}{\theta^2} + 2 \frac{\sum_{i=1}^n x_i}{\theta^3}$$

أخذ التوقع الرياضي للطرفية

$$\Rightarrow I_L = E\left(-\frac{\partial^2 \ln L}{\partial \theta^2}\right) = -\frac{n}{\theta^2} + 2 \frac{\sum_{i=1}^n E x_i}{\theta^3}$$

$$= -\frac{n}{\theta^2} + \frac{2n}{\theta^2} = \frac{n}{\theta^2}$$

وهي معلومات فيشر التي تفقد العينات العشوائية حول المعسلة  $\theta$

المقدّر النقطي ذو التباينة الأصغر

نصفه لدينا مجتمعاً إحصائياً موصوفاً بتوزيع احتمالي وسيطة المجهول  $\theta$

ولنا هذه عينات حجمها  $n$  وليكن  $T = (T_1, T_2, \dots, T_n)$  مقدّر نقطي وحيد

لتابع وسيطة  $\theta$  أي عينة  $\theta$   $E T = \psi(\theta)$  عندئذ سوف نتحقق لدينا

$$V(T) \geq \frac{(\psi'(\theta))^2}{I_L}$$

وتدعى هذه المتباينة متباينة غرامر - راو

وكيفية عمل المساهمة في هذه المتباينة يبين أن التباينة  $(T)$  أصغر ما يمكن

الطرف الأيمن من المتباينة عند غرامر وفي الحالة الخاصة إذا كانت  $\psi(\theta) = \theta$

$$V(T) \geq \frac{1}{I_L}$$

حيث الطرف الأيمن من متباينة غرامر - راو

وهو مقدار معلومات فيشر